

# 의미적 손실 함수를 통한 Cycle GAN 성능 개선

정태영<sup>1</sup>, 이현식<sup>1</sup>, 엄예림<sup>1</sup>, 박경수<sup>1</sup>, 신유림<sup>2</sup>, 문재현\*

<sup>1</sup>광운대학교 정보융합학부

<sup>2</sup>서경대학교 시각디자인과

\*한국기술거래사회

john428@naver.com, selfmd123@naver.com, yerim110324@gmail.com,

parkjh757588@gmail.com, sy10711@naver.com, smjhoon@gmail.com

\*교신저자(Corresponding Author)

## Improved Cycle GAN Performance By Considering Semantic Loss

Tae-Young Jeong<sup>1</sup>, Hyun-Sik Lee<sup>1</sup>, Ye-Rim Eom<sup>1</sup>, Kyung-Su Park<sup>1</sup>,  
Yu-Rim Shin<sup>2</sup>, Jae-Hyun Moon\*

<sup>1</sup>Dept. of Information Convergence, Kwang-Woon University

<sup>2</sup>Dept. of Visual Design, Seo-Kyung University

\*Korea Technology Transfer Agents Association

### 요 약

Recently, several generative models have emerged and are being used in various industries. Among them, Cycle GAN is still used in various fields such as style transfer, medical care and autonomous driving. In this paper, we propose two methods to improve the performance of these Cycle GAN model. The ReLU activation function previously used in the generator was changed to Leaky ReLU. And a new loss function is proposed that considers the semantic level rather than focusing only on the pixel level through the VGG feature extractor. The proposed model showed quality improvement on the test set in the art domain, and it can be expected to be applied to other domains in the future to improve performance.

**Keywords:** Style Transfer, Cycle GAN, Semantic Loss, Feature Extraction, in-domain GAN inversion


### 1. 서론

최근 다양한 산업 분야에서 생성 모델이 활용이 되고 있다. 그중, Cycle GAN은 원본 이미지의 형태를 유지하면서도 도메인만 변환하는 목적으로 의료, 자율 주행 등 다양한 분야에서 활용되고 있다.[1] 본 논문에서는 여러 분야에서 많이 사용되는 Cycle GAN 모델의 성능 개선을 위해 다른 활성화 함수와 의미적 단계까지 고려한 새로운 손실 함수를 제안한다. 특히 최근 예술 분야에서 생성 모델이 각광받는 만큼, 본 논문의 모델로 화풍 변환 모델을 제작해 성능 평가 및 예술 분야 발전에 기여하도록 한다.

### 2. 관련 연구

#### 2.1 Cycle GAN

Cycle GAN은 단순히 loss만 줄이고 특정 mode에 강하게 쏠려 서로 다른 이미지에서 같은 이미지가 생성되는 Mode Collapse 문제를 방지하기 위해 [그림 1]과 같은 순환 구조로 구현된 생성 모델이다.[2] 해당 모델의 생성자는 기본적으로 3가지 손실 함수로 구성되어 있고, 활성화 함수는 ReLU를 이용했다.



[그림 1. Cycle GAN 모델 구조도]

#### 2.2 VGG16

VGGNet은 이미지 분류 대회에서 준우승한 CNN 네트워크로 이미지 분류 및 특징을 추출할 수 있다. 본 논문에서는 VGG16을 이용해 의미적인 특징을 추출할 수 있도록 하였다.

### 3. 문제 제기

#### 3.1 활성화 함수 ReLU의 문제점

원본 Cycle GAN에서는 활성화 함수로 ReLU를 이용했다. ReLU는 음수인 값들은 0으로 만들어 이후 레이어에서 학습이 이루어지지 않는 현상이 발생할 수 있다. 따라서 음수에서는  $f(y)=0.01y$ 를 따르는 Leaky ReLU를 이용해 해당 현상을 피하고자 한다.

3.2 의미적인 손실 고려

Cycle GAN처럼 GAN 모델을 반전시킬 때는 입력 이미지의 픽셀 값을 복원시키는 것 이외에도 의미론적으로도 유의미하게 반전시켰는지 고려해야 한다.[3] Cycle GAN이 나올 당시에는 픽셀 값만을 고려해 손실 함수를 구성했었다. 본 논문에서는 의미론적인 단계도 고려하도록 하였고, 이는 4. 제안 알고리즘을 따른다.

4. 제안 알고리즘

- Feature Extractor를 이용한 Semantic loss 추가

Cycle GAN은 순환 구조를 통해 출력 이미지를 입력 이미지로 복원할 수는 있지만 픽셀 단계에 초점을 두고 복원을 하는 방식이다. 본 논문에서는 아래와 같은 수식을 기존 Cycle GAN 손실 함수에 추가해 의미적인 단계도 같이 고려를 하도록 한다.

$$L(G, F, V, D_X, D_Y) = L_{GAN}(G, D_Y, X, Y) \quad (1)$$

$$+ L_{GAN}(F, D_X, Y, X) \quad (2)$$

$$+ \lambda_1 L_{CYC}(G, F) \quad (3)$$

$$+ \lambda_2 L_{Semantic}(V, G, F)$$

X, Y는 각각의 도메인에 해당되는 데이터 셋이다. V는 VGG 모델을 이용한 Feature Extractor, G는 X에서 Y 도메인으로, F는 Y에서 X 도메인으로의 생성기이다. D는 각각의 도메인 데이터인지 판별하는 판별기이다. (1), (2)는 기존 Cycle GAN의 손실 함수와 동일한 부분이다. (1)은 일반적인 GAN에서 사용하는 loss이고, (2)는 순환 구조를 거쳐서 복원된 이미지가 처음 이미지와 동일한 지 평가하는 부분이다. (3)은 본 논문에서 추가해 준 새로운 부분으로 아래와 같은 수식으로 구성되어 있다.

$$L_{Semantic}(V, G, F) = \| V(X) - V(F(G(X))) \|_2$$

$$+ \| V(Y) - V(G(F(Y))) \|_2$$


해당 수식을 통해 기존 이미지와 순환 구조를 거치고 돌아온 이미지에 대해 VGG16을 이용한 특징 추출 값도 비교해 의미적인 단계도 고려할 수 있도록 한다. 이를 통해 픽셀 레벨에서의 측면과 의미적 레벨 두 가지 측면에서 이미지 생성이 가능해진다.

5. 실험 결과

|           | Origin CycleGAN | Leaky ReLU | Semantic Loss | Hybrid |
|-----------|-----------------|------------|---------------|--------|
| FID Score | 199.29          | 201.94     | 192.47        | 189.71 |


[표 1. 각 방식을 추가한 모델들의 FID Score 값]

모델의 정량적인 평가를 위해 모델로 사진을 고흐의 화풍으로 변환하고 실제 고흐 그림과의 FID Score를 계산했다. FID는 두 그룹의 이미지 분포 거리를 계산한다. 따라서 일반적으로 FID의 수치가 낮을수록 좋다. 실험 결과 Leaky ReLU와 Semantic loss를 추가한 Hybrid 방식이 기존 논문 방식과 각각 이용하는 것보다 최대 10점 정도 좋게 나온 것을 확인할 수 있다.



[그림 2. 원본, Cycle GAN, Hybrid 결과 비교 사진]

정성적인 평가 또한 Cycle GAN 모델을 그대로 이용한 가운데 사진보다 Hybrid 방식의 오른쪽 사진이 하늘 부분의 노이즈 해결과 풀같은 원본의 질감 특징을 더 많이 유지하면서 화풍도 잘 반영한 것을 알 수 있다.



[그림 3. Hybrid 모델의 판별자, 생성자 Loss 결과]

학습 결과 판별자와 생성자의 Loss 그래프도 크게 발산되지 않고 학습이 진행된 것을 알 수 있다.

6. 결론

본 논문에서는 기존과 다르게 의미적인 단계까지 고려한 개선된 Cycle GAN 모델을 제안해 생성된 이미지의 품질을 향상시켰다. 해당 도메인 외에도 제안된 모델을 통해 의료, 자율 주행 등 여러 도메인에 적용시켜 성능 향상을 기대할 수 있을 것이다.

본 논문은 과학기술정보통신부 정보통신창의인재양성사업의 지원을 통해 수행한 ICT멘토링 프로젝트 결과물입니다.

참고문헌

[1] 김보라, 권오연 “인공지능을 활용한 ‘합성 의료 데이터’: GAN 기술 중심으로” 한국보건산업진흥원, 2020

[2] Zhu, Jun-Yan, et al “Unpaired image-to-image translation using cycle-consistent adversarial networks.” in *ICCV*, 2017, (pp. 2223-2232)

[3] Zhu, Jiapeng, et al., “In-domain GAN inversion for real image editing,” in *ECCV*, 2020.